

# LPC


Jan Černocký ÚPGM FIT VUT Brno, [cernocky@fit.vutbr.cz](mailto:cernocky@fit.vutbr.cz)


FIT VUT Brno

## Plán

- signálový model artikulačního traktu.
- proč lineární predikce.
- odhad koeficientů filtru (aneb posuňte si své signály!)
- Levinson-Durbin
- Spektrální hustota výkonu (PSD) pomocí LPC.
- Parametry odvozené z LPC.

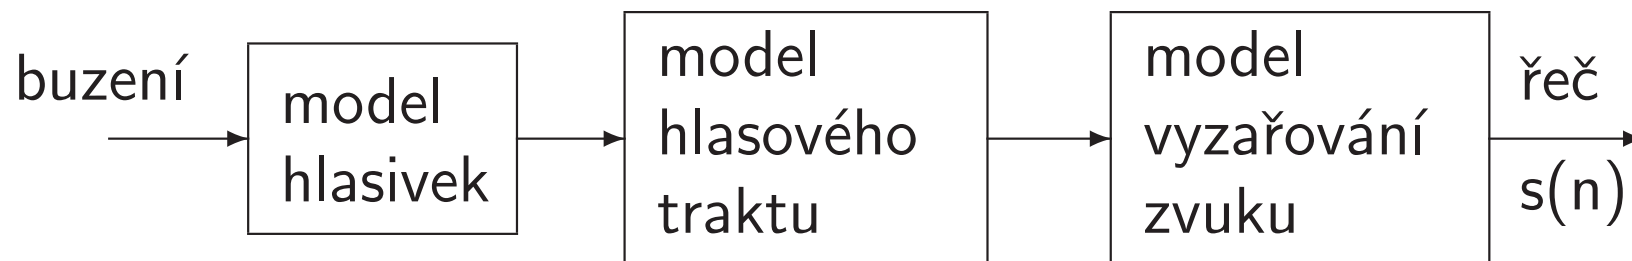
## Opakování – tvorba řeči a její model





**Cíl: Chceme odhadnout parametry tohoto modelu. Tato přednáška se bude zabývat filtrem.**

## Model artikulačního traktu




## Hlasivky

dolní propuř 2. řádu, lomová frekvence okolo 100 Hz:

$$G(z) = \frac{1}{[1 - e^{-cT_s} z^{-1}]^2} \quad (1)$$

## Hlasový trakt

kaskáda malých dvojpólových *rezonátorů* odpovídajících *formantům*.



Pro  $k$  formantů  $F_i$  s šířkami pásem  $B_i$ :

$$V(z) = \frac{1}{\prod_{i=1}^K [1 - 2e^{-\alpha_i T_s} \cos \beta_i T_s z^{-1} + e^{-2\alpha_i T_s} z^{-2}]} \quad (2)$$

kde parametry  $\alpha_i$  a  $\beta_i$  jsou určeny polohou a šířkou pásma formantů.

## Model vyzařování zvuku

$$L(z) = 1 - z^{-1} \quad (3)$$

což je horní propust.



## Dohromady ...

$$\begin{aligned} H(z) &= G(z)V(z)L(z) = \\ &= \frac{1 - z^{-1}}{(1 - e^{-cT_s} z^{-1})^2 \prod_{i=1}^K [1 - 2e^{-\alpha_i T_s} \cos \beta_i T_s z^{-1} + e^{-2\alpha_i T_s} z^{-2}]} \end{aligned} \quad (4)$$


Člen  $cT_s \rightarrow 0$ , proto můžeme krátit čitatele i jmenovatele o jeden člen  $1 - z^{-1}$ . Celkový model je tedy **celopólový** (obsahuje jen jmenovatele – čistý IIR filtr). Běžný zápis:

$$H(z) = \frac{1}{1 + \sum_{i=1}^P a_i z^{-i}} = \frac{1}{A(z)}, \quad (5)$$

kde polynom  $A(z) = 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_P z^{-P}$  má řád  $P = 2k + 1$  ( $k$  je počet formantů). Za užitečný počet pokládáme  $k=4$  či 5, proto volíme často  $P=10$  (pro  $F_s=8$  kHz). Pro vyšší vzorkovací frekvence volíme  $P$  vyšší (např. 16), abychom postihli i vf. část spektra.

## Určení parametrů modelu pomocí lineární predikce (LP)

Tvorba řeči s tímto filtrem:



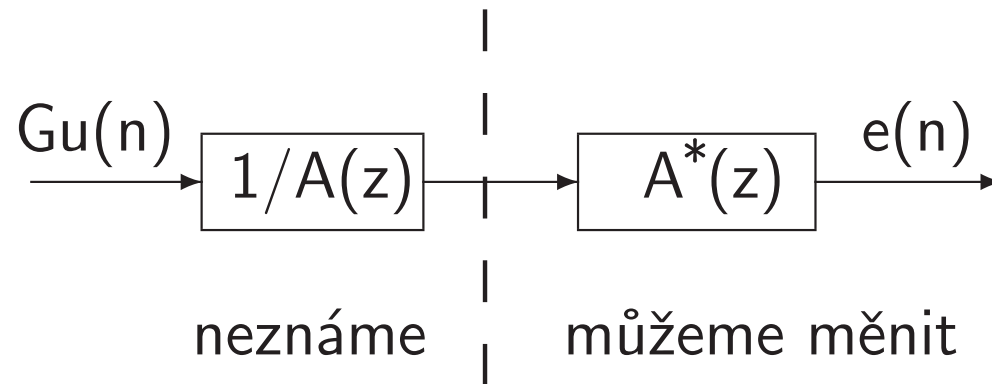
$n$ -tý vzorek řeči je tedy dán:

$$s(n) = Gu(n) - \sum_{i=1}^P a_i s(n-i) \quad (6)$$

Parametry (koeficienty) filtru  $a_i$  jsou ovšem **neznámé** a musíme je **odhadnout**, odborně **identifikovat** (system identification).

## Určení parametrů filtru

Můžeme zkonstruovat tzv. *inverzní filtr*  $A^*(z)$  s koeficienty  $\alpha_i$ :



Ukazuje se, že v případě stacionárního signálu  $s(n)$  jsou koeficienty  $\alpha_i$  *identifikovány* pomocí koeficientů  $\alpha_i$ , je-li *minimalizována energie signálu na výstupu*  $e(n)$ :  $\mathcal{E}\{e^2(n)\}$ .  
“kroutíme parametry filtru tak dlouho, dokud není energie signálu na výstupu minimální...”


## Proč “lineární predikce” ?

Předpokláme, že  $\mathcal{E}\{e^2(n)\}$  je již minimalizována, tedy že  $A^*(z) = A(z)$  a budeme tedy používat pouze označení koeficientů  $a_i$ .

$A(z)$  můžeme (trochu podivně – jako když se levou rukou drbete za pravým uchem...) zapsat jako:

$$A(z) = 1 - [1 - A(z)] \quad (7)$$

a tedy:



Signál  $\tilde{s}(n)$  je dán lineární kombinací několika předchozích vzorků, považujeme jej za *předpověď* skutečného vzorku  $s(n)$ :

$$\tilde{s}(n) = - \sum_{i=1}^P a_i s(n-i) \quad (8)$$

**Chyba predikce** je dána jako rozdíl skutečné a předpovězené hodnoty:

$$e(n) = s(n) - \tilde{s}(n) = s(n) - \left[-\sum_{i=1}^P a_i s(n-i)\right] = s(n) + \sum_{i=1}^P a_i s(n-i). \quad (9)$$

Čím lepší predikce, tím menší chyba.

V rovině  $z$ :

$$E(z) = S(z)A(z) \quad (10)$$

Výhody získání parametrů touto metodou:

- je-li  $\alpha_i = a_i$ , je chyba predikce rovna *buzení* (můžeme se tedy dostat ke vstupu do hlasového traktu bez skalpelu).
- určení koeficientů pomocí LP vede k soustavě snadno řešitelných lineárních rovnic.

## Řešení

V této etapě řešení zatím záměrně nezmiňujeme, kolik vzorků vstupního signálu máme k dispozici, sumy jsou tedy zatím bez mezí. Nenormalizovaná energie chyby predikce je dána:

$$E = \sum_n e^2(n) \quad (11)$$

Tento výraz je třeba minimalizovat. Vyjádříme jej pomocí signálu  $s(n)$  (známá veličina) a neznámých koeficientů  $a_i$ . Pro nalezení minima budeme parciálně derivovat podle každého  $a_i$ , derivace položíme rovny nule:

$$\frac{\delta}{\delta a_j} \left\{ \sum_n [s(n) + \sum_{i=1}^P a_i s(n-i)]^2 \right\} = 0 \quad (12)$$

$$\sum_n 2[s(n) + \sum_{i=1}^P a_i s(n-i)]s(n-j) = 0 \quad (13)$$

$$\sum_n s(n)s(n-j) + \sum_{i=1}^P a_i \sum_n s(n-i)s(n-j) = 0. \quad (14)$$

(15)

Označíme:

$$\sum_n s(n-i)s(n-j) = \phi(i, j), \quad (16)$$

pak

$$\sum_{i=1}^P a_i \phi(i, j) = -\phi(0, j) \quad \text{pro } 1 \leq j \leq P \quad (17)$$

Což je soustava lineárních rovnic:

$$\begin{aligned} \phi(1, 1)a_1 + \phi(2, 1)a_2 + \cdots + \phi(P, 1)a_P &= -\phi(0, 1) \\ \phi(1, 2)a_1 + \phi(2, 2)a_2 + \cdots + \phi(P, 2)a_P &= -\phi(0, 2) \\ &\vdots \\ \phi(1, P)a_1 + \phi(2, P)a_2 + \cdots + \phi(P, P)a_P &= -\phi(0, P), \end{aligned} \quad (18)$$


## Výpočet $\phi(\cdot, \cdot)$

Koeficienty odhadujeme na rámci o délce  $N$  vzorků. Dvě metody liší se v tom, jak nahlížíme na signál vně rámce (tedy pro vzorky  $n < 0$  a  $n > N - 1$ ):



## Kovarianční metoda:


signál vně rámce je **neznámý**: se vzorky mimo  $[0, N - 1]$  nemohu počítat, ani když je tam signál zpožděn.



$\Rightarrow \phi(i, j)$  a  $\phi(i + const, j + const)$  NEJSOU stejné (máme pokaždé jiný počet vzorků) - musí se řešit plná soustava lineárních rovnic. Složitě, kovarianční metoda navíc vede k **nestabilnímu** filtru  $1/A(z)$ .

## Korelační metoda:

signál vně rámce je považován za **známý, ale nulový** – mohu s ním počítat.



$\Rightarrow \phi(i, j)$  a  $\phi(i + const, j + const)$  JSOU stejné (pokaždé stejné vzorky) - soustava rovnic se nám bude dobře počítat, protože na diagonálách budou stejné hodnoty: např.

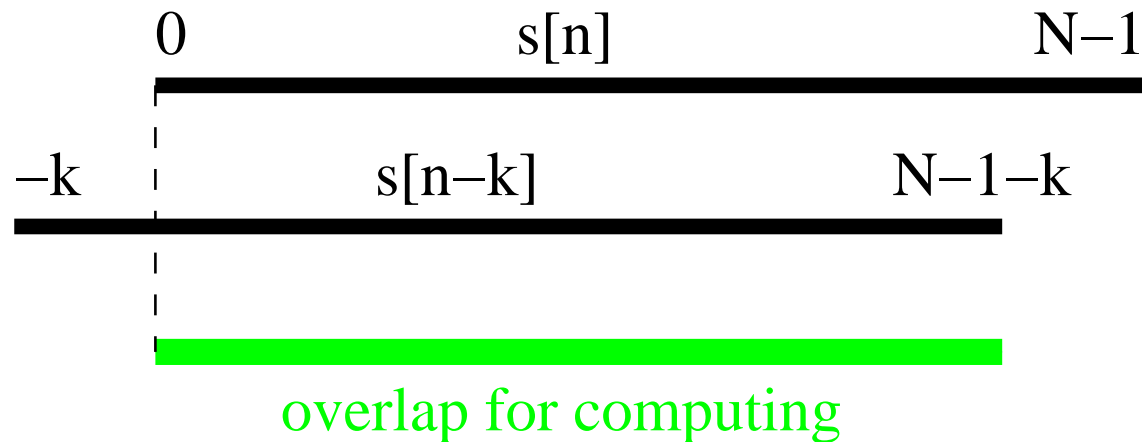
$$\phi(2, 1) = \phi(3, 2) = \phi(4, 3) = \dots$$

## Proč jsou $\phi$ autokorelační koeficienty

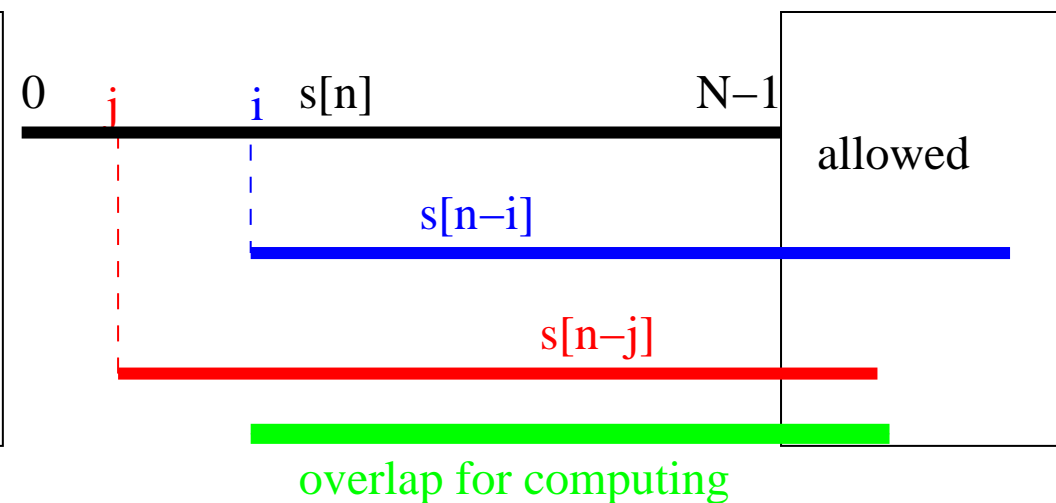
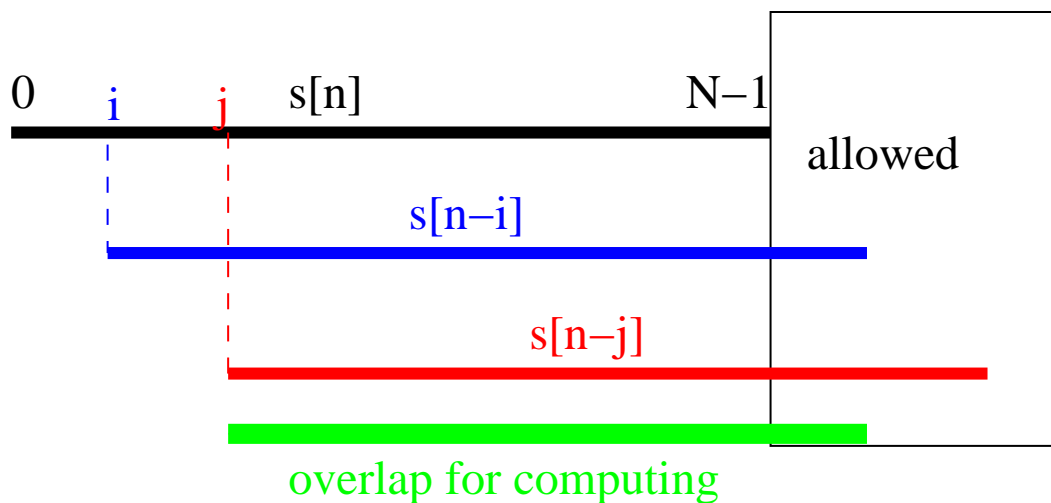
Odhad autokorelačních koeficientů (bez normalizace) pro signál o délce  $N$  pro kladné  $k$ , viz Signály a systémy, Náhodné procesy II.: <http://www.fit.vutbr.cz/~cernocky/sig>

$$R(k) = \sum_{n=0}^{N-1-k} s(n)s(n+k)$$

Korelační koeficienty “udávají podobnost signálu samotného se sebou, když ho posuneme o  $k$  vzorků”



Situace pro  $\phi(i, j)$  a  $\phi(j, i)$ :



$\Rightarrow$  pokaždé počítáme se stejnými vzorku  $\Rightarrow$  oba dva jsou rovny autokorelačnímu koeficientu  $R(|i - j|)$ . To je fajn, protože matice bude navíc ještě symetrická. Matici, která je symetrická a má na diagonálách stejné prvky, se říká **Töplitzova**.

**Výsledná soustava rovnic pro koeficienty  $a_1 \dots a_P$**

$$\begin{aligned} R(0)a_1 + R(1)a_2 + & \dots + R(P-1)a_P = -R(1) \\ R(1)a_1 + R(0)a_2 + & \dots + R(P-2)a_P = -R(2) \\ & \vdots \\ R(P-1)a_1 + R(P-2)a_2 + & \dots + R(0)a_P = -R(P), \end{aligned} \tag{19}$$

## Energie chyby predikce

Bez odvození ... pomocí LPC můžeme dostat i následující vzoreček pro výpočet **nenormalizované** energie chyby predikce:

$$E = \sum_{n=0}^{N+P-1} e^2(n) = R(0) + \sum_{i=1}^P a_i R(i) \quad (20)$$

Pokud má budící signál *normovanou energii* rovnu 1 — např. bílý šum s rozptylem 1 nebo pulsy, kde  $\frac{1}{N} \sum_{n=0}^{N-1} u^2(n) = 1$ , pak, abychom dostali tutéž energii jako  $s(n)$ , musíme nastavit gain (zesílení) filtru na:

$$G^2 = \frac{E}{N} = \frac{1}{N} \left[ R(0) + \sum_{i=1}^P a_i R(i) \right]. \quad (21)$$

... bude se nám hodit při kódování.

## Levinson–Durbin

Jelikož je matice  $\mathbf{R}$  symetrická a Töplitzova (všechny prvky na diagonálách jsou stejné), dá se k řešení soustavy 19 použít rychlý algoritmus Levinsona a Durbina:

$$E^{(0)} = R(0) \quad (22)$$

$$k_i = - \left[ R(i) + \sum_{j=1}^{i-1} a_j^{(i-1)} R(i-j) \right] / E^{(i-1)} \quad (23)$$

$$a_i^{(i)} = k_i \quad (24)$$

$$a_j^{(i)} = a_j^{(i-1)} + k_i a_{i-j}^{(i-1)} \quad \text{pro } 1 \leq j \leq i-1 \quad (25)$$

$$E^{(i)} = (1 - k_i^2) E^{(i-1)} \quad (26)$$


## Levinson-Durbin II.

- Postupně avyšujeme řád prediktoru (sloupce následující tabulky).  $a_j^{(i)}$  je  $j$ -tý koeficient prediktoru řádu  $i$ :

$$\begin{array}{cccccc} a_1^{(1)} & & & & & \\ & a_1^{(2)} & & & & \\ & & a_1^{(3)} & \cdots & a_1^{(P)} & \\ & & & & \cdots & \\ & & & & \cdots & a_2^{(P)} \\ & & & & & \cdots \\ & & & & & a_3^{(P)} \\ & & & & \ddots & \vdots \\ & & & & & a_P^{(P)} \end{array} \quad (27)$$



- podle průběhu energie chyby predikce  $E(i)$  v závislosti na řádu prediktoru lze optimalizovat tento řád:



Zvyšování řádu prediktoru nad “lom” funkce již nepřináší téměř žádné zlepšení energie chyby.

## Odhad spektrální hustoty výkonu (PSD) pomocí modelu LPC

Prozatím jsme PSD odhadovali pomocí DFT (obsahovala i “jemnou” složku způsobenou násobky frekvence základního tónu). PSD se dá ale odhadnout i pomocí frekvenční charakteristiky filtru  $1/A(z)$ :





$$\hat{G}_{LPC} = \left| \frac{G}{A(z)} \right|_{z=e^{j2\pi f}}^2, \quad (28)$$

kde  $f$  je normovaná frekvence  $f = \frac{F}{F_s}$ . Po dosazení:

$$\hat{G}_{LPC} = \frac{G^2}{\left| 1 + \sum_{i=1}^P a_i e^{-j2\pi f i} \right|^2}, \quad (29)$$


Na této spektrální hustotě výkonu se dají dobře rozeznat formanty, protože je eliminován vliv základního tónu (a tedy jemná struktura spektra, která se opakuje s  $F_0$ ).

**Příklad:** odhad spek. hustoty získaný pomocí DFT a LPC na znělém a neznělém rámci.




## Srovnání spektrogramů


Dlouhodobý spektrogram `specgram(s, 256, 8000, hamming(256), 200)` ;



Krátkodobý spektrogram `specgram(s,256,8000,hamming(50))`;



## LPC spektrogram




## Parametry odvozené z LPC koeficientů

Proč ? Koeficienty filtru  $a_i$  jsou dobré na filtrování, ale to je tak všechno:

- Špatně se kvantují (velká citlivost stability filtru na přesnost kvantizace, nejsou omezeny:  $a_i \in \langle -\infty, +\infty \rangle$ .)
- Jsou tvrdě korelovány – špatné pro rozpoznávání založené na HMM.
- Vzdálenost dvou vektorů koeficientů  $a_i$  nemá nic společného s podobností nebo nepodobností řečových rámců – špatné i pro rozpoznávání založené na přímém srovnávání parametrů (DTW)

⇒ bylo by něco lepšího ???

## PARCOR

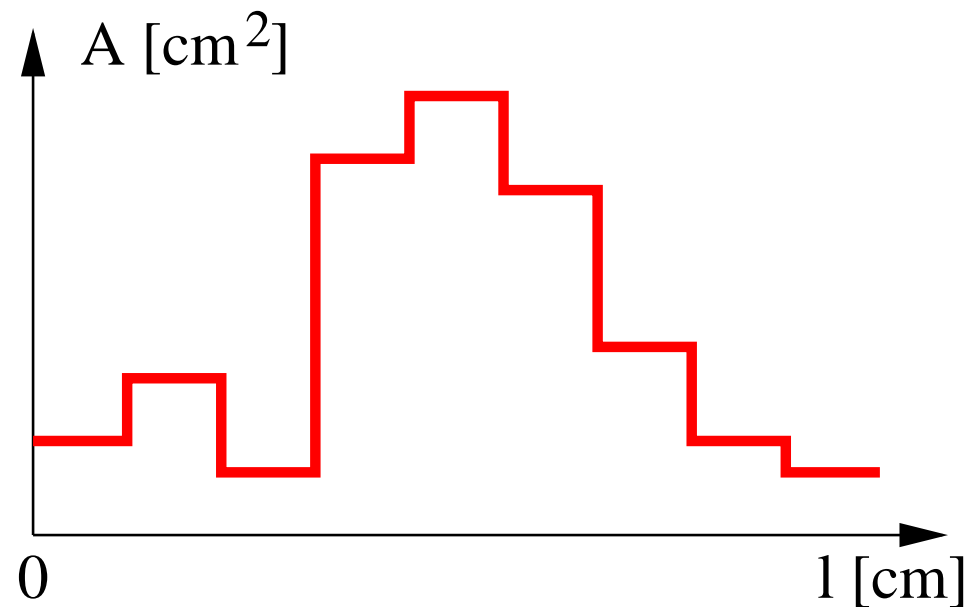


- Mezivýsledky Levinsona-Durbina: koeficienty  $k_i = a_i^{(i)}$  se označují jako *koeficienty odrazu* nebo také *koeficienty PARCOR* (partial correlation).
- Platí pro ně:  $k_i \in \langle -1, 1 \rangle$ . Jsou tedy vhodnější pro kódování než  $a_i$ .
- Sady koeficientů  $a_i$  a  $k_i$  se jedna na druhou dají jednoduše převést.



## Válcový model hlasového traktu

hlasový trakt můžeme fyzikálně modelovat pomocí válcových sekcí o stejné délce, avšak o různých průměrech (a tím i průřezech):



## Vztah válcového modelu s LPC

poměr sousedních sekcí:

$$\frac{A_{m-1}}{A_m} = \frac{1 + k_m}{1 - k_m} \quad (30)$$

pro  $m = P, P - 1, \dots, 1$ . Plocha  $A_P$  je fiktivní – skutečnou velikost neznáme, položíme tedy  $A_P = 1$ . Hodnoty  $\frac{A_{m-1}}{A_m}$  jsou pak poměry ploch – area ratios (AR). Používanější jsou logaritmické poměry ploch – log area ratios (LAR):

$$g_m = \log \frac{A_{m-1}}{A_m} = \log \frac{1 + k_m}{1 - k_m} \quad (31)$$

Výhoda  $g_m$  oproti  $k_i$  je v lineární citlivosti spektra na hodnoty. Je možné použít lineární kvantifikátor hodnot  $g_m$ . U  $k_i$  je spektrum silně citlivé na hodnoty  $k_i \rightarrow 0$ .

## LSF či LSP

*Line Spectrum Frequencies (LSF)* nebo také *Line Spectrum Pairs (LSP)*, jsou odvozeny z kořenů dvou polynomů:

$$\begin{aligned}M(z) &= A(z) - z^{-(P+1)} A(z^{-1}) \\Q(z) &= A(z) + z^{-(P+1)} A(z^{-1}).\end{aligned}\tag{32}$$


Pomocí kořenů se dají zapsat:

$$\begin{aligned}M(z) &= (1 - z^{-1}) \prod_{i=2,4,\dots,P} (1 - 2z^{-1} \cos \omega_i + z^{-2}) \\Q(z) &= (1 + z^{-1}) \prod_{i=1,3,\dots,P-1} (1 - 2z^{-1} \cos \omega_i + z^{-2}).\end{aligned}\tag{33}$$

kde  $\omega$  je normovaná kruhová frekvence  $\omega = 2\pi f$  ( $f$  je normovaná “obyčejná” frekvence). Line spectral frequencies  $f_i$  jsou v intervalu  $(0,0.5)$  a jsou seřazeny vzestupně:

$$0 < f_1 < f_2 < \dots < f_{P-1} < f_P < \frac{1}{2}.\tag{34}$$

Použijeme-li LSFs pro přenos (jsou kvantovány), můžeme v dekodéru otestovat správné dekódování tak, že zkontrolujeme jejich řazení.



## LPC-cepstrum

Cepstrální koeficienty jsme počítali pomocí DFT. Je také možno určit pomocí spektrální hustoty výkonu získané odhadem pomocí LPC:

$$\hat{G}_{LPC}(f) = \left| \frac{G}{A(z)} \right|_{z=e^{j2\pi f}}^2, \quad (35)$$

kde  $G$  je gain “syntetizačního” filtru a  $A(z)$  je polynom řádu  $P$ . V tomto případě hovoříme o LPC-cepstru (LPCC):

$$c(n) = \mathcal{F}^{-1}[\ln \hat{G}_{LPC}(f)] \quad (36)$$

Dají se odvodit následující vlastnosti LPC-cepstrálních koeficientů:

$$c(0) = \ln G^2. \quad (37)$$

Nultý LPC-cepstrální koeficient tedy nese informaci o *energii* daného řečového rámce.

Další koeficienty lze vypočítat z LPC koeficientů pomocí rekurentních vztahů:

$$\begin{aligned} c(n) &= -a_n - \frac{1}{n} \sum_{k=1}^{n-1} k c_k a_{n-k} & \text{pro } 1 \leq n \leq P \\ c(n) &= -\frac{1}{n} \sum_{k=1}^{n-1} k c_k a_{n-k} & \text{pro } n > P \end{aligned} \tag{38}$$

⇒ velmi jednoduchý převod.

## Použití LPCC koeficientů

- LPCC koeficienty jsou jednou z parametrizací používaných v *rozpoznávacích řeči*. Jejich výhodou je, že jednotlivé koeficienty jsou méně korelovány než například LPC koeficienty  $a_i$ , v rozpoznávacích postavených na skrytých Markovových modelech (hidden Markov models – HMM) se obejdeme bez plných kovariančních matic  $\Sigma$  a vystačíme s vektory rozptylů. Více v kapitole o rozpozávání pomocí HMM.
- pomocí dvou sad LPCC koeficientů můžeme jednoduše spočítat logaritmickou spektrální vzdálenost (logarithmic spectral distance) mezi dvěma řečovými rámci (nepříjemná definice s integrálem přejde na prostou Euklidovu vzdálenost dvou vektorů LPCC).